PATENT ABSTRACTS OF JAPAN

(11)Publication number : 2000-330582
(43)Date of publication of application : 30.11.2000

(51)Int.Cl. G10L 13/00
G10L 11/00

(21)Application number : 11-137123
(22)Date of filing : 18.05.1999

(71)Applicant : NIPPON TELEGR & TELEPH CORP <NTT>
(72)Inventor : TAKANO SATORU
ABE MASANOBU

(54) SPEECH TRANSFORMATION METHOD, DEVICE THEREFOR, AND PROGRAM RECORDING MEDIUM

(57)Abstract:
PROBLEM TO BE SOLVED: To provide a speech transformation method in which fine components are maintained even if a fundamental frequency is transformed, by considering that the small components of an amplitude spectrum before flattening have an influence on sound quality.
SOLUTION: According to this speech transformation method, a transformed speech is obtained by processing an input speech signal by FFT by multiplying it by a complementary Gaussian window with a three-pitch length of the fundamental frequency; obtaining a logarithmic amplitude spectrum therefrom; processing the spectrum by inverse FFT to obtain a complex cepstrum; dividing it into low quefrency components and high quefrency components; processing each of them by FFT (S0602, S0603) to obtain a spectrum envelope component and sound source fine components; expanding and contracting the sound source fine components in the frequency domain with a ratio of the fundamental frequency to a target fundamental frequency (S0604); summing this and the spectrum envelope component to obtain a transformed spectrum; and converting it into the time domain.

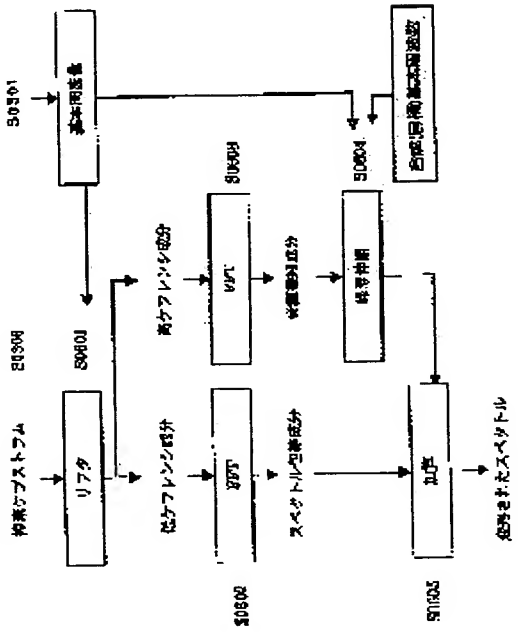

LEGAL STATUS

[Date of request for examination] 08.11.2001
[Date of sending the examiner's decision of rejection]
[Kind of final disposal of application other than the examiner's decision of rejection or application converted registration]
[Date of final disposal for application]
[Patent number] 3557124

[Date of registration] 21.05.2004

[Number of appeal against examiner's decision of rejection]

[Date of requesting appeal against examiner's decision of rejection]

[Date of extinction of right]

(19)日本国特許庁（ＪＰ）　(12)**公開特許公報**（Ａ）　(11)特許出願公開番号
特開2000－330582
（P2000－330582A）
(43)公開日　平成12年11月30日(2000.11.30)

(51)Int.Cl.⁷	識別記号	ＦＩ		テーマコード（参考）
Ｇ１０Ｌ　13/00		Ｇ１０Ｌ　7/02		Ｄ
11/00		9/16		

審査請求　未請求　請求項の数５　ＯＬ　（全 10 頁）

(21)出願番号　特願平11－137123

(22)出願日　平成11年５月18日(1999.5.18)

(71)出願人　000004226
日本電信電話株式会社
東京都千代田区大手町二丁目３番１号
(72)発明者　▲高▼野　哲
東京都新宿区西新宿三丁目19番２号　日本電信電話株式会社内
(72)発明者　阿部　匡伸
東京都新宿区西新宿三丁目19番２号　日本電信電話株式会社内
(74)代理人　100066153
弁理士　草野　卓　（外１名）

(54)【発明の名称】　音声変形方法、その装置、及びプログラム記録媒体

(57)【要約】
【課題】　規則合成における基本周波数変形を高品質で可能とする。
【解決手段】　入力音声信号に対し、その基本周波数の３ピッチ分の長さで相補的ガウス窓を掛けてＦＦＴし、その対数振幅スペクトルを求め、これを逆ＦＦＴして複素ケプストラムを得、これを低ケフレンシ成分と高ケフレンシ成分に分け、それぞれをＦＦＴして（Ｓ０６０２，Ｓ０６０３）、スペクトル包絡成分と、音源微細成分を得、基本周波数と目標基本周波数比で音源微細成分を周波数領域で伸縮し（Ｓ０６０４）、これとスペクトル包絡成分とを加算して変形されたスペクトルを得、これを時間領域に変換して変形音声を得る。

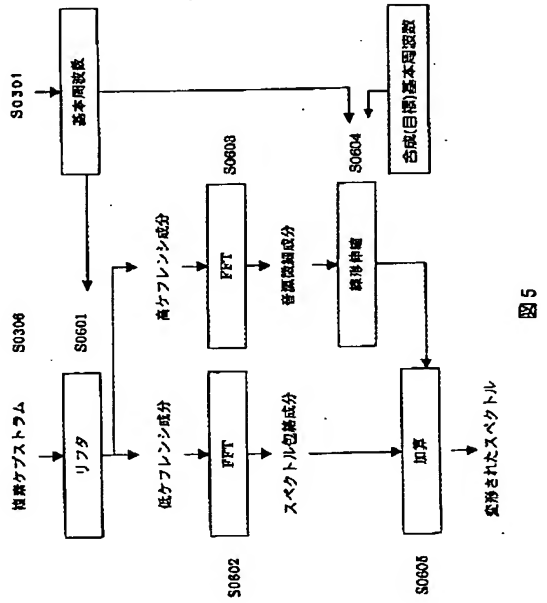

図５

1

【特許請求の範囲】

【請求項１】　入力音声信号に時間窓を乗じる過程と、その時間窓を乗じた入力音声信号を周波数領域に変換して短時間スペクトルを分析する過程と、
前記スペクトルからスペクトル包絡と微細構造を分離する過程と、
前記入力音声信号から基本周波数を分析する過程と、
前記基本周波数と目標基本周波数との比に比例して前記微細構造を周波数領域で伸縮する過程と、
前記スペクトル包絡と前記伸縮された微細構造とを加算してスペクトルを合成する過程と、
前記合成されたスペクトルを時間領域の信号に変換する過程と、を有する音声変形方法。

【請求項２】　前記基本周波数に反比例するように前記時間窓の窓長を決定する過程を有し、
前記時間窓を乗じる過程は、前記時間窓として前記決定された窓長の相補的ガウス窓関数を乗じる過程であることを特徴とする請求項１記載の音声変形方法。

【請求項３】　入力音声信号に時間窓を乗じる時間窓乗算部と、
その時間窓が乗算された入力音声信号を周波数領域に変換して短時間スペクトルを分析するスペクトル分析部と、
前記スペクトルからスペクトル包絡と微細構造を分離するスペクトル分離部と、
前記入力音声信号から基本周波数を分析する基本周波数分析部と、
前記基本周波数と目標基本周波数との比に比例して前記微細構造を周波数領域で伸縮する微細構造伸縮部と、
前記スペクトル包絡と前記伸縮された微細構造とを加算してスペクトルを合成するスペクトル合成部と、
前記合成されたスペクトルを時間領域の信号に変換する信号合成部と、を有する音声変形装置。

【請求項４】　前記基本周波数に反比例するように前記時間窓の窓長を決定する窓長設定部を有し、
前記時間窓乗算部では、前記時間窓として前記決定された窓長の相補的ガウス窓関数が用いられる、ことを特徴とする請求項３記載の音声変形装置。

【請求項５】　請求項１又は２の何れか１項に記載の音声変形方法をコンピュータが実行するプログラムを記録した記録媒体。

【発明の詳細な説明】

【０００１】

【発明の属する技術分野】この発明は、テキストからの音声合成をはじめとする規則音声合成技術において、合成目標の韻律に合わせるために音声素片を基本周波数変形する際に生じる合成音声の品質劣化を抑制したり、自然音声を分析合成して声質変形する際に生じる品質劣化を抑制することを目的とする音声合成方法及びプログラム記録媒体に関するものである。

2

【０００２】

【従来の技術】最近主流となっているＰＳＯＬＡ合成法をはじめとする波形合成方式は、音声波形をそのまま使うことから、変形量が少ない際に高音質な反面、変形量が大きいと歪みが目立つ。高音質を目指すためには、変形量を少なくするために大量の素片を必要としてしまう。また、自然な響きと個人性を保持することを長所とするＣＨＡＴＲ法は大量の音声データを持ち、その中から出力する文に応じて適合する音韻を選びだす方式で、高音質な反面、信号処理を行わないので一般に所望の基本周波数パタンで音声を合成することは難しい。

【０００３】柔軟な変形を行うためには、音声を分析してモデル化するボコーダ型の分析合成方式が有利であるが、従来のボコーダは波形合成に対して音質が劣るというのが定説である。ボコーダの中でも短時間スペクトル分析をもとにした合成法では、ハミング窓にもとづく短時間スペクトルを平滑化したものをもとに合成しているのがほとんどである。

【０００４】

【発明が解決しようとする課題】人間の発声では、声帯と声道はつながっており、基本周波数の調節に伴って声道形状にいくらかの変化が生じることから、基本周波数の変化とともにスペクトルの構造も変化する。そこで、音声の基本周波数変形には基本周波数の変化量に応じて、スペクトル形状を変換することも必要になる。しかし、従来のボコーダ型合成法は声帯音源情報と声道形状にあたるスペクトル包絡情報を分離してモデル化しており、異なる基本周波数パターンを持っている変換対象の素片のスペクトルをそのまま用いて合成するのがほとんどであった。その場合、合成する基本周波数とスペクトルの不整合を防ぐために、スペクトル包絡は振幅スペクトルを平滑化したものを用いていた。

【０００５】この発明では平滑化する前の振幅スペクトルの微細成分が音質に影響をおよぼしていると考え、基本周波数を変形しても微細成分を保持するような音声変形方法を提供する。

【０００６】

【課題を解決するための手段】この発明によれば、入力音声信号に時間窓を乗じ、その時間窓を乗じた音声信号を周波数領域に変換して短時間スペクトルを分析し、そのスペクトルからスペクトル包絡と微細構造を分離し、また入力音声信号から基本周波数を抽出し、その基本周波数と目標基本周波数との比に比例して微細構造を周波数領域で伸縮し、その伸縮された微細構造とスペクトル包絡を加算してスペクトル合成し、その合成されたスペクトルを時間領域に変換する。

【０００７】基本周波数に反比例するように時間窓の窓長を決定し、その窓長の相補的ガウス窓関数を時間窓として用いる。

（１）音声の一般的性質として、スペクトル包絡は声道

の特性を反映し、微細構造は基本周波数とその高調波成分を示す。基本周波数が変化する場合には、スペクトル包絡は変化せず、微細構造が基本周波数に応じて変化する。

（２）本発明によれば、目標周波数に音声を変形しても、スペクトル包絡は変化せず、微細構造が基本周波数に応じて変化する。したがって、変形された音声を聴取しても自然性を維持できる。

（３）さらに、音声を切出すときに用いる時間窓として音声の基本周波数の周期に比例した窓長をもつガウス相補型時間窓を用いることによって、基本周波数成分を反映した微細構造の抽出が損なわれない。そのため、この発明により目標基本周波数が得られるように基本周波数を変化させて音声を変形してもその自然性が確保できる。

【０００８】短時間スペクトルを求める場合、フーリエ変換の前に窓関数をかけて音声波形を切り出すが、従来の合成法では周波数分解能が高いハミング窓を用いるものがほとんどであった。この発明の実施例では、相補的なガウス窓を用いた短時間スペクトルをもとに分析することが特徴である。ハミング窓による短時間スペクトルと相補的なガウス窓（文献１参照）による短時間スペクトルを図９に示す。比較のためにハミング窓による短時間スペクトルを－１ｄｂ下方にシフトしている。スペクトルの包絡は似ているが、微細成分の上下動が大幅に異なることがわかる。相補的なガウス窓による短時間スペクトルはスペクトル包絡をとってももとのスペクトルに近い一方、微細な成分もある程度併せ持っている。

【０００９】

【発明の実施の形態】図１にこの発明の基本構成を示す。入力音声はステップＳ０２０１のスペクトル分析部で短時間スペクトル分析および基本周波数抽出をされ、それをもとにステップＳ０２０２のスペクトル変形部で入力音声と目標合成音声の基本周波数の違いに応じてスペクトル変形を行い、変形されたスペクトルに基づいてステップＳ０２０３の重複加算合成部で重複加算法により合成音声を生成する。

【００１０】以下、この発明を規則音声合成に適用する場合の実施例を述べる。図１中のステップＳ０２０１にあたる短時間スペクトル分析の処理例を図２に示す。入力音声は図３に示すように固定フレーム間隔ΔＴで、つまりΔＴづつ順次シフトさせながら分析され、ｎフレーム目の分析結果の短時間スペクトルＸ（ω，ｎ）はフレームの中心の時間位置ｎΔｔと結びついたパラメータとなる。まず、ステップＳ０３０１で入力音声については各フレーム中心点ｎΔｔでの基本周波数を抽出する。実施例ではＴＥＭＰＯ法（文献１参照）にもとづいて基本周波数抽出に加えて有声無声判定も行う。各フレームについて、フーリエ変換の次数をＮとするとき、ステップＳ０３０２で音声波形からフレーム中心の前後Ｎ／２点を切り出し、ステップＳ０３０３では当該フレームのステップＳ０３０１で抽出した基本周波数に基づき、３ピッチ分の長さの相補的なガウス窓をかけてステップＳ０３０４でＦＦＴにより短時間スペクトルを求める。この窓かけの時間長、つまり短時間スペクトルを求める時間長は１～５ピッチ分程度が好ましい。５ピッチより長くすると、不要な波形が加わって平均化され、微細成分を取り出すことが困難になる。好ましくは３ピッチ分程度がよい。ステップＳ０３０５では求めた短時間スペクトルの絶対値の対数をとり、対数振幅スペクトルを得る。ステップＳ０３０６では対数振幅スペクトルの逆フーリエ変換を行い、複素ケプストラムＣ（ω，ｎ）を得る。

【００１１】従来法の例としてＳＴＲＡＩＧＨＴ法では図４に示すように、ステップＳ０３０４の振幅スペクトルに対してステップＳ０５０１で平滑化を行い、音源成分にあたる微細成分を除去している。この発明では微細成分を除去せず、保持した状態でスペクトル変形を行う。図１中のステップＳ０２０２にあたるスペクトル変形の処理例を図５に示す。ステップＳ０２０１で求めた入力音声の基本周波数をもとにケプストラムリフタを構成し、図２で求めた複素ケプストラムＣ（ω，ｎ）に対して、ステップＳ０６０１で低ケフレンシ成分と高ケフレンシ成分に分離する。この分離は例えば基本周波数と対応する点よりわずか（２０～３０程度（ＦＦＴが１０２４点の場合））低い点を境界として分ければよい。低ケフレンシ成分はスペクトル包絡のケプストラムであり、この低ケフレンシに対しステップＳ０６０２でＦＦＴを行うことによりスペクトル包絡Ｅ（ω）が得られる。高ケフレンシ成分は音源成分のケプストラムであり、この高ケフレンシ成分に対し、ステップＳ０６０３でＦＦＴを行うことにより音源成分であるスペクトルの微細成分Ｒ（ω）が得られる。これらスペクトル包絡Ｅ（ω）とスペクトルの微細成分Ｒ（ω）の例を図６に示す。

【００１２】音源成分Ｒ（ω）については、微細成分保持および合成基本周波数との整合をとるためにステップＳ０６０４で入力音声の基本周波数と合成音声の基本周波数の比ｒをもとに線形伸縮を行う。このＲ（ω）に対する線形伸縮を、この実施例では図７に示す。Ｒ（ω）は離散フーリエ変換をもとにした離散データであるために、Ｒ（ｎ）（ｎは整数）と表すことができ、周波数方向に伸縮すると離散値のサンプリング点からはずれる。そのため、伸縮後の微細成分のスペクトルＲ′（ｍ）（ｍは整数）は図７に示すようにｒｎ≦ｍ＜ｒ（ｎ＋１）となるｎに対してＲ′（ｍ）＝｛（ｒ（ｎ＋１）－ｍ）Ｒ（ｒｎ）＋（ｍ－ｒｎ）Ｒ（ｒ（ｎ＋１））｝／ｒにより線形補間により求める。また、伸縮を行うために、基本周波数を高くする場合（ｒ＞１）には高域において有効周波数をはみ出す部分があるため、この部分を捨て去る。逆に基本周波数を低くする場合（ｒ＜１）に

は高域のスペクトルを作る必要がある。この実施例では足りなくなった周波数でそこを中心に線対称となるスペクトルを用いる（スペクトルの折り返し）ことにより高域を作成する。ステップＳ０６０５においてスペクトル包絡と変形された音源成分の加算を行い、合成基本周波数にあったスペクトルを再構成する。

【００１３】音源成分Ｒ（ω）に対する線形伸縮の他の例を以下に示す。

（１）伸縮前の微細構造のスペクトルＲ（ｍ）（０≦ｍ＜Ｎ／２、ｍは整数、Ｎはフレーム長）をフーリエ展開（好ましくはＦＦＴ）して展開係数ρ（ｋ）を得る（０≦ｋ＜Ｎ／２、ｋは整数、Ｎはフレーム長）。ここで、$\rho(k)=\sum_{m=0}^{N/2-1} R(m)\exp(2\pi jmk/N)$（ｊは虚数単位）と算出する。また、$R(m)=2/N\sum_{k=0}^{N/2-1}\rho(k)\exp(2\pi jmk/N)$という関係がある。

（２）基本周波数Ｆ₀と目標基本周波数Ｆ₀′とから伸縮後の微細構造のスペクトルＲ′（ｍ）を基底関数ｅｘｐにおける変数ｘを（Ｆ₀／Ｆ₀′）倍、つまり（Ｆ₀／Ｆ₀′）ｘと置換して展開する。

【００１４】$R'(m)=2/N\sum_{k=0}^{N/2-1}\rho(k)\exp(2\pi jmk/N\times(F_0/F_0'))$

このような演算により、周波数幅Ｆ₀内における伸縮前の微細構造のスペクトルＲ（ｍ）における成分は周波数幅Ｆ₀′に伸縮される。周波数は離散的に与えられるため、上記の線形補間によれば顕著に平滑化されたり、Ｆ₀′＜Ｆ₀のときにｆ／２（ｆは標本化周波数）を定義できないという問題が生じる。しかし、この方法によればかかる問題を生じず、一義的に解を与えることができる。

【００１５】図１中のステップＳ０２０３にあたる重複加算合成部は図８に示す。この合成部はＳＴＲＡＩＧＨＴ法に由来するものであり、詳細は文献１を参照のこと。ステップＳ０６０５で再構成されたスペクトルをもとにステップＳ０９０１で対数スペクトルを求め、ステップＳ０９０２でフーリエ逆変換により複素ケプストラムを求め、ステップＳ０９０３で最小位相化したスペクトルを求める。ステップＳ０９０４では有声音成分としてそのスペクトルに、位相操作として周波数領域でオールパスフィルタをかけて、ステップＳ０９０５でフーリエ逆変換により、インパルス応答を求めて、ステップＳ０９０６では合成する基本周波数の逆数に当たるピッチ間隔で重複加算する。また、ステップＳ０９０７では無声音成分としてそのスペクトルのインパルス応答を求め、ステップＳ０９０８で乱数列をたたみこんだものをステップＳ０９０９で固定間隔で重複加算する。ステップＳ０９１０では有声音成分と無声音成分をステップＳ０２０１で求めた有声無声判定をもとに混合して合成音声を得る。

【００１６】次に実験例を述べる。不均一な基本周波数Ｆ₀の変形が連続する規則合成音についてプリファレンステストで評価した。対象とする音声はそれぞれ１～２秒程度の長さのもの３種類である。ＣＶ－ＶＣ素片で合成対象を覆うように素片を用いた。Ｆ₀の変形量が大きく、単位が短い場合となるように選んだ、合成法としてＰＳＯＬＡ、ＳＴＲＡＩＧＨＴ、本発明方法の３種類について比較した変形対象のＦ₀を平行移動することにより全体的に高くする場合と、全体的に低くする場合でどう変わるか検討した。Ｆ₀の平行移動はもとのＦ₀の１．２倍、１．４倍（Ｆ₀を高くする）、１／１．２倍、１／１．４倍（Ｆ₀を低くする）の４通りである。被験者は９人で３種類の合成音のうち２個を１組とした刺激音をランダムな順番で提示した。

【００１７】その結果を図１０に示す。上から順に３組ずつ、もとの合成Ｆ₀パタンと４種類の平行移動したＦ₀パタンでの結果である。各横バーの中の数字は同一テキストについての左の合成音と右の合成音を比較したときに左の合成音を選んだ比率を示す。例えば１番上の横バーでは同一テキストに対し、左のＰＳＯＬＡによる合成音の方が、ＳＴＲＡＩＧＨＴによる合成音より音質がよいとした率が３８．９％であることを示す。図中の◎は危険率が１％、○は危険率５％で有意な差を示す。この結果から、Ｆ₀を低くする変形でＰＳＯＬＡよりＳＴＲＡＩＧＨＴや本発明方法が良い評価を得ている。Ｆ₀を高くする変形ではこの発明方法とＳＴＲＡＩＧＨＴを比較するとこの発明方法の方が選択され、しかも◎、○印のものについてはこの発明方法によれば従来法より高品質が得られることの信頼性が高いことが理解される。

【００１８】

【発明の効果】以上述べたようにこの発明によれば、入力音声のスペクトルをスペクトル包絡と微細成分（構造）とに分離し、その微細成分について目標基本周波数と原基本周波数との比に応じて伸縮させた後、スペクトル包絡と合成し、この合成スペクトルを時間領域に戻すことにより、スペクトル包絡は変化せず、微細成分のみを基本周波数に応じて変化させることができ、変形された音声を聴取しても自然性が維持される。

【００１９】特にガウス相補型時間窓を用いると、微細成分（構造）の抽出が良好に行われ、変形音声の自然性がより良好に確保できる。この発明を分析合成音声および、規則音声合成に適用したところ、先にも示したように従来法に比べて高音質な合成音を得られることが確認できた。

［参考文献］

１．河原「聴覚の情景分析と高音質音声分析合成法ＳＴＲＡＩＧＨＴ」音講論，１－２－１，ｐｐ１８９－１９３，１９９７（９）

【図面の簡単な説明】

【図１】この発明の基本構成を示す図。

【図２】図１中の音声分析部の処理手順の例を示す図。

7

【図３】音声信号に対する分析フレームと時間窓との関係例を示す図。
【図４】従来の音声分析の一部を示す図。
【図５】図１中のスペクトル変形部の処理手順の例を示す図。
【図６】音源成分（微細成分）とスペクトル包絡の分離例を示す図。

8

＊【図７】図５中の線形伸縮の例を示す図。
【図８】図１中の重複加算合成部の具体的処理手順の例を示す図。
【図９】ガウス窓とハミング窓とを用いた短時間スペクトルの各例を示す図。
【図１０】実験結果を示す図。

【図１】

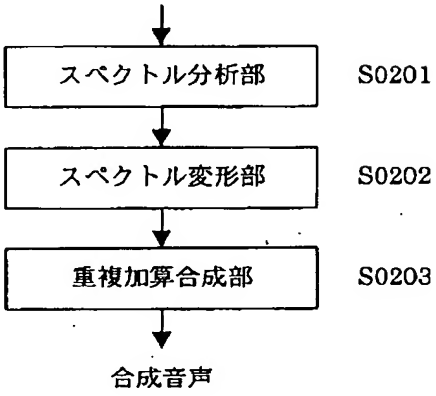

図１

【図３】

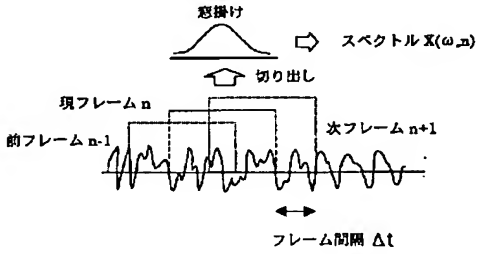

図３

【図６】

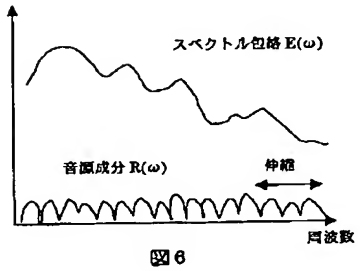

図６

【図７】

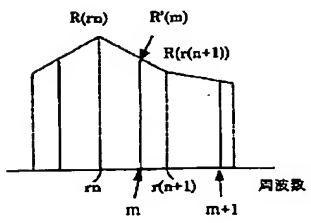

図７

【図２】

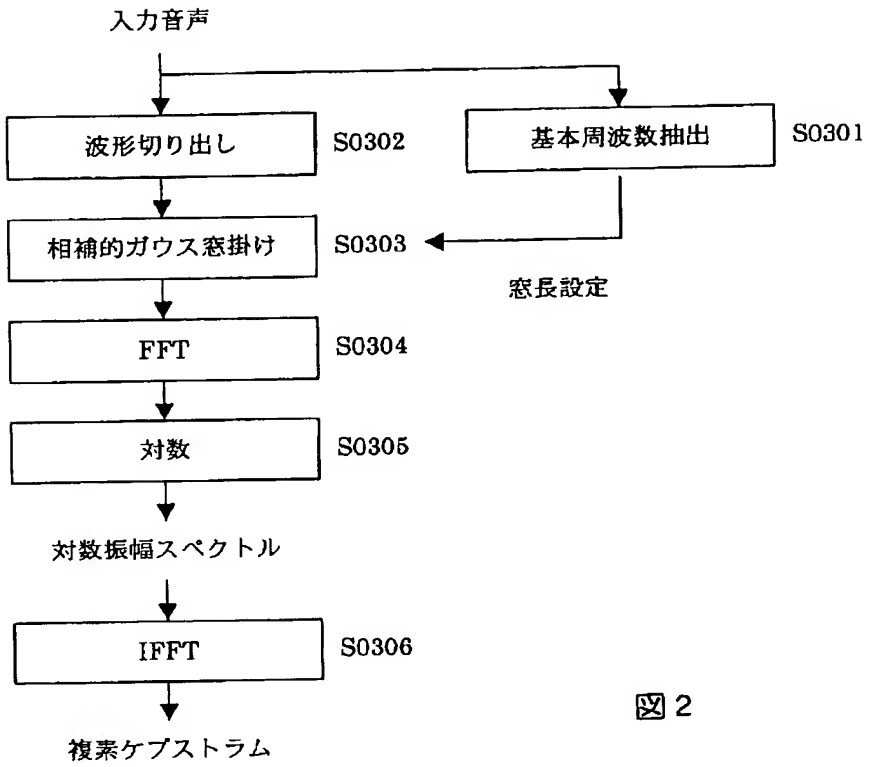
入力音声
波形切り出し
S0302
基本周波数抽出
S0301
相補的ガウス窓掛け
S0303
窓長設定
FFT
S0304
対数
S0305
対数振幅スペクトル
IFFT
S0306
複素ケプストラム

図２

【図４】

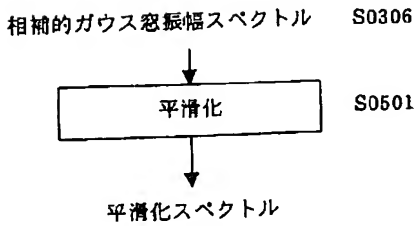
相補的ガウス窓振幅スペクトル
S0306
平滑化
S0501
平滑化スペクトル

図４

【図５】

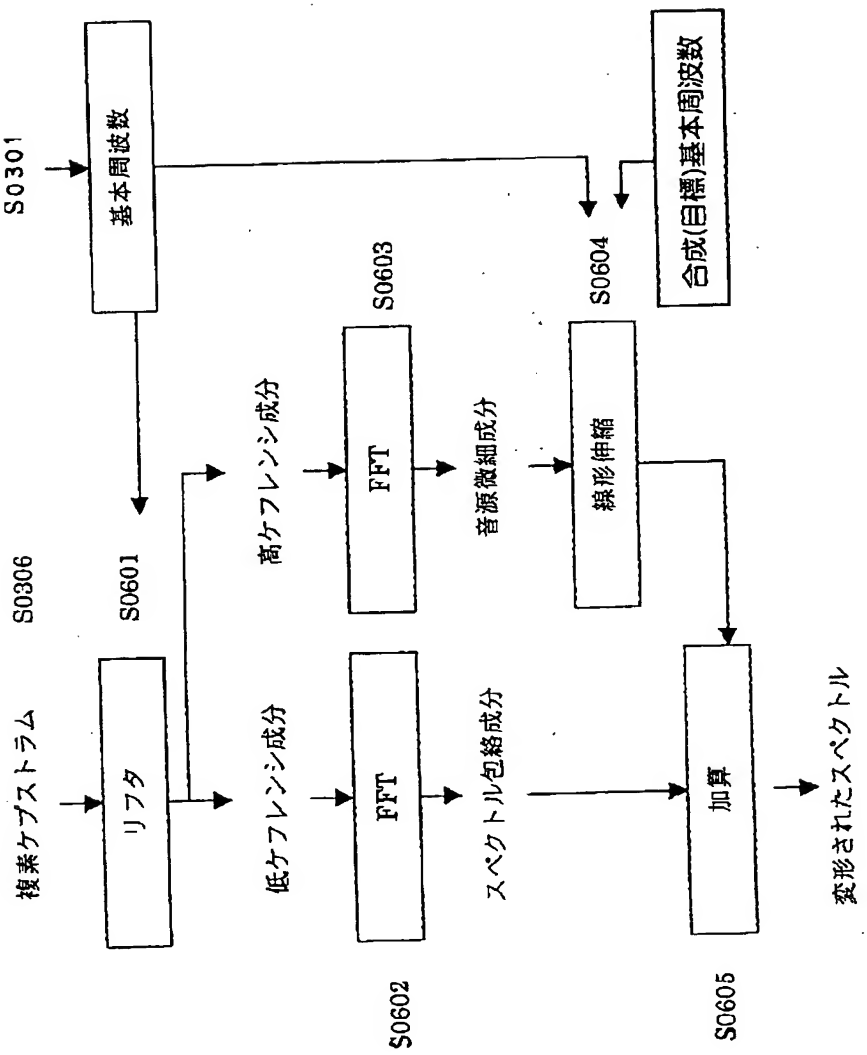
S0301
基本周波数
S0306
S0601
S0603
S0604
合成(目標)基本周波数
複素ケプストラム
リフタ
高ケフレンシ成分
FFT
音源微細成分
線形伸縮
低ケフレンシ成分
FFT
スペクトル包絡成分
加算
変形されたスペクトル
S0602
S0605

図５

【図８】

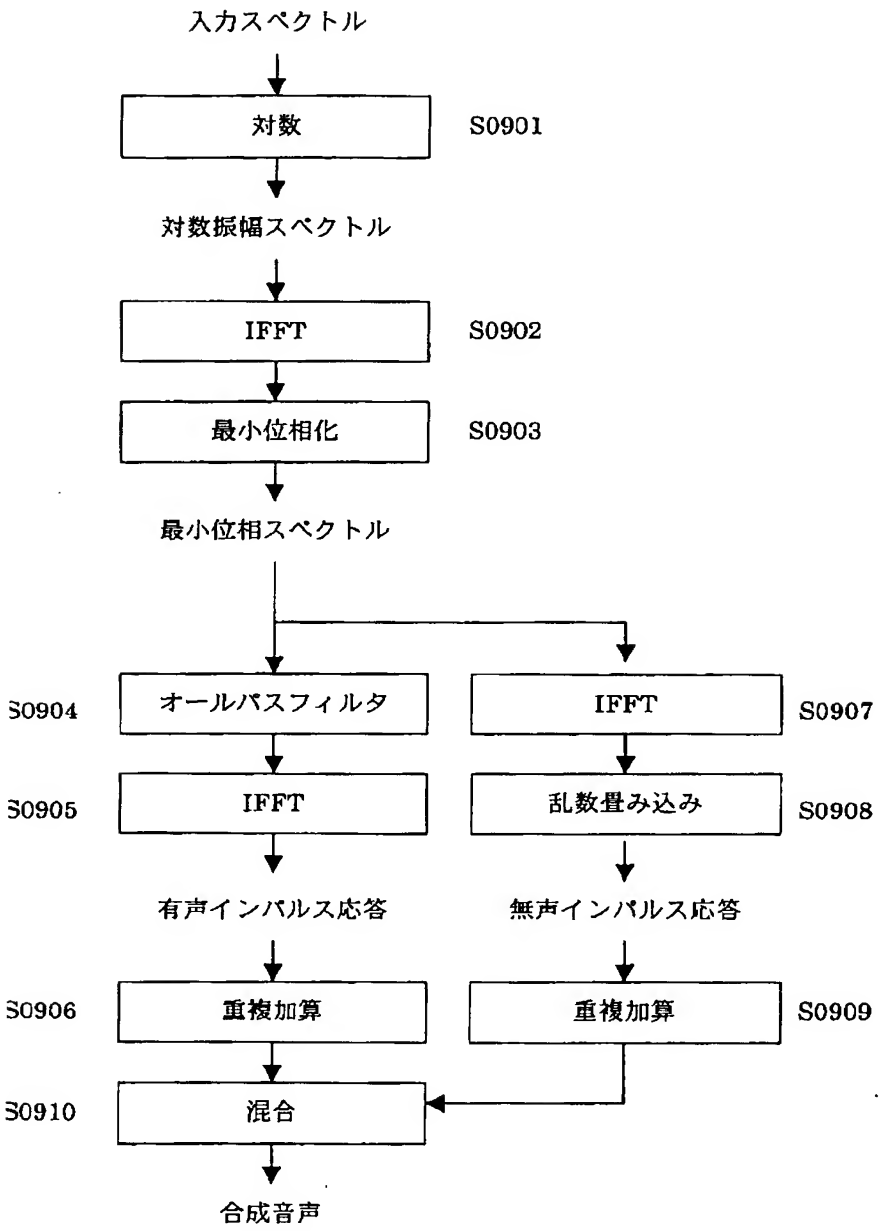
入力スペクトル
対数
S0901
対数振幅スペクトル
IFFT
S0902
最小位相化
S0903
最小位相スペクトル
S0904
オールパスフィルタ
IFFT
S0907
S0905
IFFT
乱数畳み込み
S0908
有声インパルス応答
無声インパルス応答
S0906
重複加算
重複加算
S0909
S0910
混合
合成音声

図８

【図９】

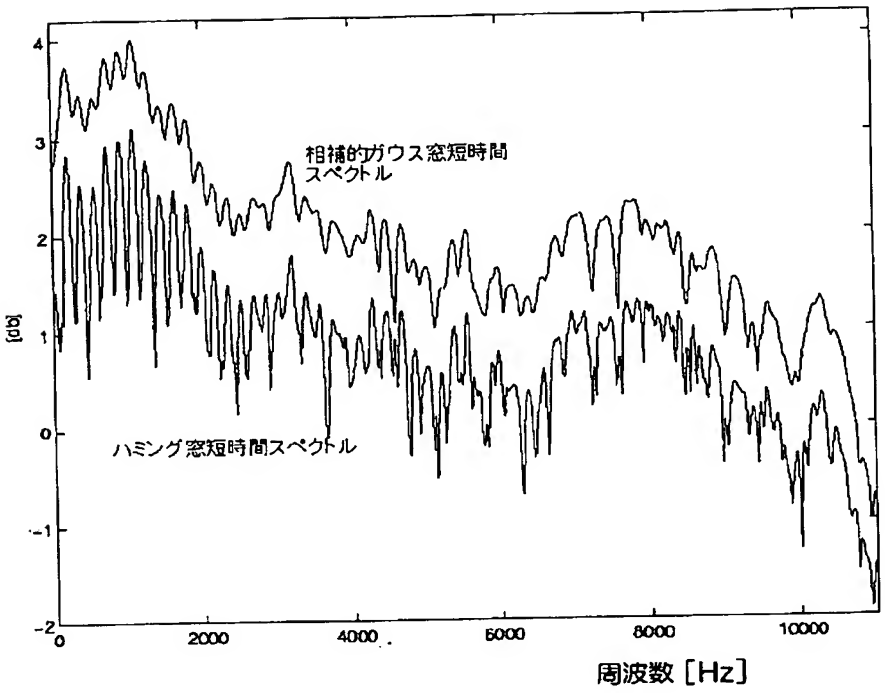
相補的ガウス窓短時間
スペクトル
ハミング窓短時間スペクトル
[pb]
4
3
2
1
0
-1
-2
0
2000
4000
6000
8000
10000
周波数［Hz］

図９

【図１０】

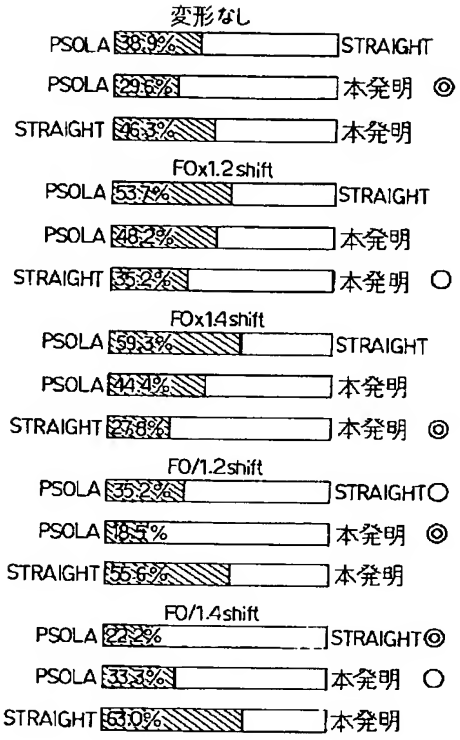
変形なし
PSOLA 38.9% STRAIGHT
PSOLA 29.6% 本発明 ◎
STRAIGHT 46.3% 本発明
FOx1.2shift
PSOLA 53.7% STRAIGHT
PSOLA 48.2% 本発明
STRAIGHT 35.2% 本発明 ○
FOx1.4shift
PSOLA 59.3% STRAIGHT
PSOLA 44.4% 本発明
STRAIGHT 25.8% 本発明 ◎
FO/1.2shift
PSOLA 35.2% STRAIGHT○
PSOLA 38.5% 本発明 ◎
STRAIGHT 55.6% 本発明
FO/1.4shift
PSOLA 22.2% STRAIGHT◎
PSOLA 33.3% 本発明 ○
STRAIGHT 63.0% 本発明

図10